

# 価値観モデリングを利用した協調フィルタリングにおけるモデル関係学習の提案

高間康史 白石雄也 柴田祐樹

首都大学東京

*ytakama@tmu.ac.jp*

**概要** 本稿では価値観モデリングを用いた協調フィルタリングを拡張し、ユーザモデルとアイテムモデル間の関係を学習するアプローチを提案する。情報推薦システムにおける近年の研究動向として、多様性やロングテールアイテムなど、精度以外の要素を考慮することが挙げられる。そのような場合、ユーザの嗜好をある程度満足しながら受け入れ可能なアイテムを推薦することが重要であり、利用者が解釈可能な推薦の実現が要求される。既存の行列分解ベース協調フィルタリングと比較して、価値観モデリングではユーザの意思決定に影響を与えるアイテムの属性としてモデル化するため解釈容易という利点がある。価値観モデリングを用いた行列ベース協調フィルタリングの既存研究では、ユーザモデル・アイテムモデル間の関係を手動で設定していたが、本発表では機械学習により評価値行列から学習するアプローチを提案する。実験結果により、提案手法の有効性を示す。

**キーワード** 情報推薦、協調フィルタリング、価値観、ロングテール

## 1 はじめに

情報推薦は大規模情報を利用するために必要不可欠な情報処理技術の一つである。オンラインショッピングサイトやニュースキュレーションサービス、観光地推薦などで実用化されている。

情報推薦の目的は、ユーザが好むであろうアイテムを提示することにある。従って、情報推薦システムは対象ユーザが下すであろう評価値をなるべく正確に予測し、その値の高いものからユーザに推薦するアイテムを選択することが一般的である。しかし、情報推薦技術の発展により、近年では多様性 [1, 5, 12, 27, 28], セレンディピティ [7, 20], ロングテールアイテム [8, 15, 21] など、正確さ以外の要因も注目されている。そのような場合には、ユーザの嗜好との合致は目的関数としてではなく、制約として扱うべきと考える。例えば、健康的な料理のレシピを推薦したい場合 [3]、対象ユーザの多くは高カロリー・高脂質な食事を好むと考えられるため、単に健康面だけを考慮した推薦は受け入れてもらえない可能性が高い。すなわち、対象ユーザが受け入れてくれると期待できる程度には嗜好を満たす中で、健康的な料理のレシピを推薦する必要がある。

ユーザの嗜好をある程度満たしつつ、人気のないアイテムを推薦することが要求される場合も考えられる。推薦対象アイテムがホテルやレストランなどのように容量に制約がある場合、すなわち室数や座席数に限りがある場合、誰もが気に入りそうな人気あるアイテムを推薦するのではなく、人気はそれほどでもないが対象ユーザが気に入りそうなアイテムを推薦する必要がある。人気

のないアイテムはロングテールアイテムと呼ばれるが、そのようなアイテムを推薦することは顧客満足度やロイヤリティを向上するのに貢献することが指摘されている [16]。

人気はないが受け入れ可能なアイテムを推薦するためには、解釈容易性が重要であると考える。推薦する理由やアイテムの説明を提示する手法の研究は、ユーザの満足度向上、推薦システムの説得性や信頼性向上の観点から、近年注目を集めている [25]。解釈可能なモデルを採用することは、推薦説明の提示に有効であることが期待できる。

上記を踏まえ、本稿では価値観に着目する。価値観とは、物事の優先順序や価値を決める際の根底となるものであり、情報推薦の文脈ではアイテムの評価や推薦の受け入れに関係する要因の一つといえる。推薦システムに導入しやすい価値観のモデル化手法として、本稿では評価一致率 (rate matching rate, RMRate) を採用する。RMRate はアイテムが持つ各属性が、ユーザのアイテム評価に与える影響を定量的に見積もる手法であり、内容ベース推薦や近傍ベース協調フィルタリングに導入した場合の有効性が報告されている [6, 24]。RMRate を利用する利点の一つは、その解釈容易性にある。行列分解ベースの協調フィルタリングではアイテム、ユーザは潜在ベクトルとして表現されるのに対し、RMRate を用いた場合はアイテムの属性上にモデルが構築されるため、その意味を把握しやすい。

RMRate を行列ベース協調フィルタリングに導入した手法が提案されている [22]。この手法では RMRate を用いてユーザモデル、アイテムモデルを求め、それぞれ行列として表現する。両行列の列はアイテムの持つ属性

に対応するため、ユーザに対するアイテムの推薦度は両行列の積により計算できる。前述の通り、既存の行列分解ベース協調フィルタリングでは潜在因子の意味を解釈するのが困難であるのに対し、RMRate を用いたユーザ・アイテムモデルは解釈しやすい点で利点があることが期待できる。文献 [22] ではユーザ・アイテムモデル間の関係を行列（モデル関係行列）として表現する手法も提案しており、Yahoo! Movie データセットを用いた実験で SVD (singular value decomposition)[19] や NMF (non-negative matrix factorization)[13] と同等の推薦精度を達成しつつ、人気アイテム以外を推薦可能であることを示している。

既存研究 [22] ではモデル関係行列を手動で設定していたが、本稿ではこれを機械学習のアプローチで獲得する手法を提案する。予測誤差と BPR (Bayesian personalized ranking)[17] に基づく 2 種類の学習アプローチを提案し、2 種類のデータセットを用いた評価実験により既存の代表的な行列分解ベース協調フィルタリングと同等の精度を達成しつつ人気のないアイテムを推薦可能であることを示す。

## 2 関連研究

### 2.1 行列分解ベース協調フィルタリング

行列分解ベース協調フィルタリングは、評価値行列の次元を削減することで推薦精度を向上させることを目的としている [11]。アイテム数・ユーザ数よりも圧倒的に少數の潜在因子を見つけることにより次元を削減する。様々な行列分解ベース協調フィルタリングが提案されているが、本節では推薦精度の高さなどからよく用いられる代表的な手法として SVD, NMF, PMF を紹介する。

#### 2.1.1 SVD (Singular Value Decomposition)

SVD[19] は  $N$  ユーザ  $\times O$  アイテムからなる評価値行列  $R$  を行列  $U_K, S_K, V_K$  により式 (1) の様に近似する。ここで、 $U_K$  と  $V_K$  はそれぞれ  $N \times K$  のユーザ行列、 $O \times K$  のアイテム行列である。

$$\hat{R} = U_K S_K V_K^T \quad (1)$$

$K$  は  $\hat{R}$  と  $R$  の二乗誤差が最小となるように決定する。

#### 2.1.2 NMF (Non-negative Matrix Factorization)

NMF[13] は式 (2) のように  $R$  を近似する非負の潜在因子行列  $U, V$  を求める。近似を求める際の距離指標としてユークリッド距離や Kullback-Leibler divergence が用いられる。

$$\hat{R} = U V^T \quad (2)$$

### 2.1.3 PMF (Probabilistic Matrix Factorization)

PMF[18] は確率的アプローチによる行列分解手法であり、実際の評価値と予測値の差  $|r_{i,j} - u_i v_j^T|$  がガウス分布に従うとみなす。このモデルの条件付確率分布は式 (3) で与えられる。ここで、 $N(x|\mu, \sigma^2)$  は平均  $\mu$ 、分散  $\sigma^2$  のガウス分布、 $I_{i,j}$  は式 (4) で定義される関数である。

$$p(R|U, V, \sigma^2) = \prod_{i=1}^N \prod_{j=1}^O [N(r_{i,j}|u_i v_j^T, \sigma^2)]^{I_{i,j}} \quad (3)$$

$$I_{i,j} = 1 \text{ (if user } i \text{ rated item } j) / 0 \text{ (otherwise)} \quad (4)$$

式 (3) の対数尤度を最大化する  $U, V$  を求め評価値の予測に用いる。

### 2.2 値観ベースの情報推薦

価値観はユーザがアイテムを評価したり、購入したりする際の意思決定に影響を与える要因の一つであり、マーケティング [26]、Web インテリジェンス [2] などの分野で応用されている。価値観を内容ベース推論や近傍ベース協調フィルタリングに導入する手法が提案されている [6, 23, 24]。本節では、本稿で用いる評価一致率 (RMRate) [6] について紹介する。

RMRate の計算では、アイテムに対する総合評価だけでなく、アイテムの各属性に対する評価も利用可能であることを前提とする。例えば映画の属性がストーリー、配役、音楽などであったとし、あるユーザが気に入った映画に対していつもストーリーを高評価している場合、ストーリーは当該ユーザの意思決定に大きな影響を与えていると考えられる。RMRate はこれを定量的にモデル化するものであり、式 (5) で定義される。

$$RMRate_{ik} = \frac{\sum_{x_j \in I_i} \delta(p_{ij}, p_{ij}^k)}{|I_i|} \quad (5)$$

ここで、 $I_i$  はユーザ  $u_i$  により評価されたアイテムの集合、 $p_{ij} \in \{pos, neg\}$  は  $u_i$  が  $x_j$  に下した総合評価値の極性、 $p_{ij}^k \in \{pos, neg\}$  はアイテム  $x_j$  の  $k$  番目の属性に対する  $u_i$  の評価の極性である。本稿では、ユーザ毎に総合評価値の平均を求め、総合評価や属性評価がこの平均以上の場合に好評 (pos) とみなす。関数  $\delta(x, y)$  は  $x$  が  $y$  と等しいときに 1、異なるときに 0 を返すとする。 $|x|$  は  $x$  の要素数である。

RMRate によるユーザモデルは少数の評価情報から安定した推定が可能であることが報告されている [6]。近傍ユーザベース協調フィルタリングに導入した手法も提案されており [23]、従来の近傍ユーザベースよりも低い MAE を達成した結果が得られている。RMRate をアイテムベース協調フィルタリングに導入する手法 [24] で

は、その解釈容易性を生かして推薦説明を生成する手法も提案されている。

### 3 提案手法

本節では提案手法MCFPV (Matrix-based Collaborative Filtering employing Personal Values) を提案する。MCFPVはユーザモデリング、アイテムモデリング、モデル関係行列構築、推薦アイテム決定から構成される。モデル関係行列においてユーザ・アイテムモデル間の関係を柔軟に設定するために、本稿では機械学習により構築する。

#### 3.1 ユーザ・アイテム行列

ユーザモデル行列 $M_u$ は $N$ (ユーザ) $\times L$ (属性)行列として表現される。この行列において、 $(i, j)$ のセルはユーザ*i*の属性*j*に対するRMRateを保持する。アイテム行列 $M_v$ も同様の情報を保持するが、アイテムあたりの評価件数は通常ユーザあたりの件数よりも多いことが想定されるため、好評・不評に分けてRMRateを求める。従って、 $M_v$ は $O$ (アイテム) $\times 2L$ の行列となる。1~ $L$ 列目が好評、 $L+1$ ~ $2L$ 列目が不評のRMRateに対応する。アイテムに対し属性が好評(不評)の場合に高いRMRateを持つとき、その属性に満足する(しない)ユーザはそのアイテムを気に入る(入らない)傾向にあることを意味する。

#### 3.2 推薦アイテムの決定

従来の行列分解ベース協調フィルタリングでは評価値行列を直接分解していたのに対し、特に手動でモデル関係行列を設定する場合には $M_u$ と $M_v$ の積は必ずしも評価値行列を近似するものではない。そこでMCFPVでは式(6)により推薦度のスコアを定義する。

$$S_{pred} = M_u \times M_R \times M_v^T \quad (6)$$

ここで、 $M_R(L \times 2L)$ は $M_u$ と $M_v$ の関係を表すモデル関係行列である。 $M_R$ の詳細は次節に述べる。推薦時には、推薦対象ユーザに対しこのスコアの降順にアイテムをソートし、上位のアイテムを推薦する。

#### 3.3 モデル関係行列

モデル関係行列 $M_R$ は、 $M_u, M_v$ 間の関係を適切に表現することで推薦精度を向上するために導入する。 $M_R$ は各要素(セル)を $w_{i,j}$ として、式(7)の様に表現される。

$$M_R = \begin{pmatrix} w_{1,1} & \cdots & w_{1,L} & w_{1,L+1} & \cdots & w_{1,2L} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ w_{L,1} & \cdots & w_{L,L} & w_{L,L+1} & \cdots & w_{L,2L} \end{pmatrix} \quad (7)$$

先行研究[22]では $M_R$ を手動で設定していたが、本稿では2種類の機械学習アプローチによりこれを求める。

#### 3.3.1 予測誤差に基づく学習

ユーザ*i*のアイテム*j*に対する予測スコア $\hat{s}_{i,j}$ は式(8)により計算される。

$$\hat{s}_{i,j} = \sum_{k=1}^L \sum_{l=1}^{2L} u_{i,k} v_{j,l} w_{k,l} \quad (8)$$

ここで、 $u_{i,k} \in M_u$ ,  $v_{j,l} \in M_v$ ,  $w_{k,l} \in M_R$ である。本稿で、損失関数 $L(M_R)$ は式(9)により定義する。

$$L(M_R) = \sum_{r_{i,j} \in D_{train}} (r_{i,j} - \hat{s}_{i,j})^2 + \lambda \|M_R\|^2 \quad (9)$$

ここで、 $r_{i,j}$ は訓練データ(評価値行列) $D_{train}$ の総合評価であり、 $\|\cdot\|$ はフロベニウスノルムを意味する。

本稿ではSGD[9, 10, 11]により上記目的関数を最小化する $M_R$ を求める。Algorithm1に疑似コードを示す。8行目で、 $w_{k,l}$ は $r_{i,j}$ に関する損失関数の勾配に基づき更新する。 $\eta$ は学習率であり、学習の収束速度を制御する。本稿では[10]を参考に、 $0.1/\sqrt{t}$ ( $t$ はステップ数)とする。

---

#### Algorithm 1 Stochastic gradient descent for MCFPV

```

1: Initialize matrix  $M_R$ 
2:  $\eta \leftarrow 0.1$ ,  $t \leftarrow 1$ 
3: while  $t < \text{maxT}$  do
4:   Shuffle training data  $r_{i,j} \in D_{train}$  randomly
5:   for  $r_{i,j} \in D_{train}$  do
6:     for  $k=1$  to  $L$  do
7:       for  $l=1$  to  $2L$  do
8:          $w_{k,l} \leftarrow w_{k,l} + \eta \{u_{i,k} v_{j,l} (r_{i,j} - \hat{s}_{i,j}) - \lambda w_{k,l}\}$ 
9:       end for
10:      end for
11:    end for
12:    if  $M_R$  is converged then
13:      break
14:    end if
15:     $t \leftarrow t + 1$ 
16:     $\eta \leftarrow \frac{0.1}{\sqrt{t}}$ 
17: end while

```

---

#### 3.3.2 BPRに基づく学習

BPRは各ユーザ $u_i$ に対しアイテムの総合評価に関するランキング $>_i$ を学習する。これは、式(10)に示す事後確率を最小化する問題に帰結する。

$$p(M_R | >_i) \propto p(>_i | M_R) p(M_R) \quad (10)$$

各ユーザ(集合 $S_U$ )が独立に行動(評価)することを仮定して、全ユーザを考慮した尤度関数は以下の様に表される。

$$\Pi_{u_i \in S_U} p(>_i | M_R) = \Pi_{(i,p,n) \in D_{train}} p(v_p >_i v_n | M_R) \quad (11)$$

$$p(v_p >_i v_n | M_R) = \frac{1}{1 + e^{-\hat{s}_{i,p,n}}} \quad (12)$$

$$\hat{s}_{i,p,n} = \hat{s}_{i,p} - \hat{s}_{i,n} \quad (13)$$

$$D_{train} = \{(i, p, n) | u_i \in S_U \wedge v_p \in S_{V,i}^+ \wedge v_n \in S_V - S_{V,i}^+\} \quad (14)$$

ここで、 $S_V$  は全アイテム集合、 $S_{V,i}^+$  はユーザ  $u_i$  が気に入ったアイテムの集合である。目的関数は式 (16) で定義される。

$$L_{BPR}(M_R) = \ln \Pi_{u_i \in S_U} p(M_R | >_i) \quad (15)$$

$$= \sum_{(i,p,n) \in D_{train}} \ln \frac{1}{1 + e^{-\hat{s}_{i,p,n}}} - \lambda \|M_R\|^2 \quad (16)$$

$w_{k,l}$  の更新式はこの勾配として求められる。

$$w_{k,l} \leftarrow w_{k,l} + \eta \left\{ \frac{e^{-\hat{s}_{i,p,n}}}{1 + e^{-\hat{s}_{i,p,n}}} u_{i,k} (v_{p,l} - v_{n,l}) - \lambda w_{k,l} \right\} \quad (17)$$

BPR を用いた学習アルゴリズムは Algorithm1 を以下の様に修正することで得られる。

- 4 行目 :  $r_{i,j}$  を  $(i, p, n)$  に置換
- 8 行目 : 更新式を式 (17) に置換

## 4 評価実験

### 4.1 データセット

Yahoo! Movie<sup>1</sup> と Hotpepper beauty<sup>2</sup> の 2 種類のデータセットを用いて評価実験を行った。各データセットについて、総合・属性評価値のスケール、属性を表 1 に示す。前処理として、評価値が極端に少ないユーザ・アイテムを削除した。具体的には、Yahoo! Movie からは評価件数が 5 件以下のユーザ・アイテム、Hotpepper Beauty からは 1 件以下のユーザ・アイテムをそれぞれ削除した。表 2 に、各データセットのユーザ数、アイテム数、評価件数、密度を示す。BPR の訓練データセット  $D_{train}$  を求める際には、評価値 4 以上の場合に好評とみなした。

表 1 データセットの概要

データセット	評価値	Attributes
Yahoo! Movie	1,2,3,4,5	Story, cast, scenario, visuals, music
Hotpepper Beauty	1,2,3,4,5	Atmosphere, service, skill, price

表 2 データセットの規模

データセット	ユーザ	アイテム	評価	密度
Yahoo! Movie	18,507	6,746	523,730	0.00420
Hotpepper Beauty	31,976	8,101	72,386	0.00028

### 4.2 実験手順

提案手法の比較対象として、SVD、NMF、PMF でも実験を行う。実験では double cross validation[4] を採用し、以下の手順で行う。検証するハイパーパラメータの範囲は、 $\lambda \in \{10^{-1}, 10^{-2}, 10^{-3}, 10^{-14}, 10^{-5}\}$ 、潜在因子数  $K \in \{5, 10, 20, 40, 80\}$  とした。 $K$  は SVD、PMF、NMF に関するものであり、提案手法 MCFPV の次元はアイテムの持つ属性数に等しい。

1. データセット  $D$  を 3 つの部分集合  $D_i$  に分割。
2. 各  $D_i$  に対し以下のステップを適用。
  - (a)  $D^{-i} = D - D_i$  とする。
    - i.  $D^{-i}$  を 3 つの部分集合  $D_j^{-i}$  に分割。
    - ii. 各ハイパーパラメータの組み合わせを用いて、 $D_j^{-i}$  を検証用データ、 $D^{-i} - D_j^{-i}$  を訓練データとして cross validation を実行。
    - iii. 2(a)ii の結果に基づき最良のハイパーパラメータを選択。
  - (b)  $D^{-i}$  を訓練データ、 $D_i$  をテストデータとして評価を行う。
3. 全ての  $D_i$  について評価指標の平均値を求める。

評価には top- $N$  推薦タスクを採用し、P@ $N$  (precision at  $N$ )、R@ $N$  (recall at  $N$ )[14]、Div@ $N$  (diversity at  $N$ ) により評価する。P@ $N$  は対象ユーザに対する上位  $N$  件の推薦リスト内に好評のアイテムが含まれる割合、R@ $N$  は対象ユーザに対する全好評アイテムのうち、推薦リストに含まれる割合である。Div@ $N$  は多様性に関する指標であり、少なくとも一人のユーザに推薦されたアイテムの異なり数である。実験に用いたデータセットにおけるユーザ・アイテムあたりの評価件数を参考に、 $N$  は 3 とする。

<sup>1</sup><http://movies.yahoo.co.jp/>

<sup>2</sup><http://beauty.hotpepper.jp/>

表 3 実験結果 (Yahoo! Movie)

	P@3	R@3	Div@3
MCFPV(PRE)	0.578	0.431	<b>2700</b>
MCFPV(BPR)	0.578	0.431	2699
MCFPV(D1)	0.578	0.431	2659
SVD	0.617	0.449	2127
PMF	0.586	0.445	2167
NMF	<b>0.620</b>	<b>0.451</b>	1966

表 4 実験結果 (Hotpepper Beauty)

	P@3	R@3	Div@3
MCFPV(PRE)	<b>0.894</b>	0.869	3207
MCFPV(BPR)	0.893	<b>0.870</b>	<b>3250</b>
MCFPV(D1)	<b>0.894</b>	0.869	3142
SVD	0.892	0.869	2909
PMF	0.890	0.867	2868
NMF	0.892	0.868	2805

### 4.3 実験結果

表 3, 4 に Yahoo! Movie と Hotpepper Beauty データセットの実験結果をそれぞれ示す。表において、MCFPV (PRE) は 3.3.1 節に示した手法、MCFPV(BPR) は 3.3.2 節に示した手法である。MCFPV(D1) は、モデル関係行列を対角行列として手動で設定した場合 [22] である。

表より、P@3 と R@3 に関しては NMF が Yahoo! Movie データセットに対して最も良い結果となっている。Hotpepper Beauty データセットでは MCFPV が最も良い結果となっているが、手法間の差はそれほど大きくない。この結果は、提案手法 (MCFPV) は行列分解ベース協調フィルタリングの代表的手法と同等の推薦精度を達成していることを意味する。

一方で、Div@3 では MCFPV が他の手法より高い値を示しており、ユーザに対し多様なアイテムを推薦できていることがわかる。さらに、本稿で提案する機械学習を用いたアプローチでは、手動でモデル関係行列を設定した場合 (MCFPV(D1)) よりも良い結果となっている。

より詳細に考察するために、Div@3 とアイテムの人気度 (評価件数) の関係を図 1, 2 に示す。図 1 より、Yahoo! Movie データセットにおいて MCFPV は評価件数が 80 件以下のアイテムを他の手法より多数推薦していることがわかる。Hotpepper Beauty データセットでは、MCFPV は評価件数 10 件以下のアイテムを多数推薦している。また、2 種類の機械学習アプローチ間の差は大きくないこともわかる。これらの結果より、機械学習の方法によらず、提案手法は人気のないアイテムの推薦に適していることが示された。

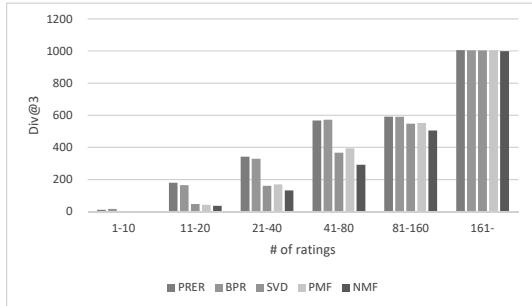


図 1 Div@3 と人気度の関係 (Yahoo! Movie)

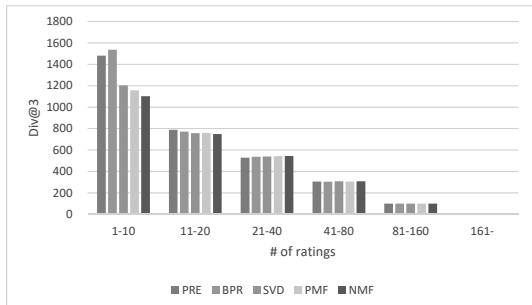


図 2 Div@3 と人気度の関係 (Hotpepper Beauty)

### 5 まとめ

本稿では、MCFPV を拡張し、モデル関係行列を機械学習アプローチにより獲得する手法を提案した。2 種類のデータセットを用いた評価実験により、MCFPV は SVD, NMF, PMF と同等の推薦精度を達成しつつ、多様なアイテムを推薦可能であることを示した。

今後の計画として、得られたユーザ・アイテムモデル及びモデル関係行列を詳細に分析し、解釈可能性について考察する予定である。また、価値観モデリングが持つ解釈容易性の特性を生かし、推薦説明を提示可能な情報推薦システムの構築も計画している。

### 謝辞

本研究の一部は科研費 JP16K12535 によるものである。また、国立情報学研究所の IDR データセット提供サービスにより株式会社リクルートテクノロジーズから提供を受けた「リクルートデータセット」を利用した。

### 参考文献

- [1] Panagiotis Adamopoulos and Alexander Tuzhilin, On Over-specialization and Concentration Bias of Recommendations: Probabilistic Neighborhood Selection in Collaborative Filtering Systems, 8th ACM Conference on Recommender Systems (RecSys '14), pp. 153-160, 2014.
- [2] Jilin Chen, Gary Hsieh, Jalal U. Mahmud, and Jeffrey Nichols, Understanding Individuals' Personal Values from Social Media Word Use, 17th ACM Conference on Computer Supported Cooperative Work & Social Computing (CSCW'14), pp. 405-414, 2014.

- [3] David Elsweiler, Christoph Trattner, and Morgan Harvey, Exploiting Food Choice Biases for Healthier Recipe Recommendation, 40th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR'17), pp. 575-584, 2017.
- [4] P. Filzmosera, B. Liebmann, and K. Varmuza, Repeated double cross validation, Chemometrics, Vol. 23, No. 4, pp. 160–171, 2009.
- [5] Daniel M. Fleder and Kartik Hosanagar, Recommender Systems and Their Impact on Sales Diversity, 8th ACM Conference on Electronic Commerce (EC'07), pp. 192-199, 2007.
- [6] Shunichi Hattori and Yasufumi Takama, Recommender System Employing Personal-Value-BasedUser Model, Journal of Advanced Computational Intelligence and Intelligent Informatics (JACIII), Vol. 18, No. 2, pp. 157-165, 2014.
- [7] Jonathan L. Herlocker, Joseph A. Konstan, Loren G. Terveen, and John T. Riedl, Evaluating Collaborative Filtering Recommender Systems, ACM Trans. Inf. Syst., Vol. 22, No. 1, pp. 5-53, 2004.
- [8] Dietmar Jannach, Lukas Lerche, Fatih Gedikli, and Geoffray Bonnin, What recommenders recommend - An analysis of accuracy, popularity, and sales diversity effects, User Modeling, Adaptation, and Personalization (UMAP2013), pp. 25-37, 2013.
- [9] Santosh Kabbur, Xia Ning, and George Karypis, FISM: Factored Item Similarity Models for top-N Recommender Systems, 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'13), pp. 659-667, 2013.
- [10] Alexandros Karatzoglou, Xavier Amatriain, Linas Baltrunas, and Nuria Oliver, Multiverse Recommendation: N-dimensional Tensor Factorization for Context-aware Collaborative Filtering, 4th ACM Conference on Recommender Systems (RecSys'10), pp. 79-86, 2010.
- [11] Yehuda Koren, Robert Bell, and Chris Volinsky, Matrix Factorization Techniques for Recommender Systems, Computer, Vol. 42, No. 8, pp. 30-37, 2009.
- [12] Ralf Krestel and Nima Dokooohaki, Diversifying Product Review Rankings: Getting the Full Picture, 2011 IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology (WI-IAT'11), pp. 138-145, 2011.
- [13] Daniel D. Lee and H. Sebastian Seung, Algorithms for Non-negative Matrix Factorization, NIPS, pp. 556-562, 2000.
- [14] Ling Liu and M. Tamer Zsu, Encyclopedia of Database Systems (1st ed.), Springer, 2009.
- [15] Yoon-Joo Park and Alexander Tuzhilin, The Long Tail of Recommender Systems and How to Leverage It, 2008 ACM Conference on Recommender Systems (RecSys'08), pp. 11-18, 2008.
- [16] C. Porcel, A. Tejeda-Lorente, M.A. Martnez, and E. Herrera-Viedma, A hybrid recommender system for the selective dissemination of research resources in a Technology Transfer Office, Inf. Sci., Vol. 184, No. 1, pp. 1-19, 2012.
- [17] S. Rendle, C. Freudenthaler, Z. Gantner, L. Schmidt-Thieme, BPR: Bayesian Personalized Ranking from Implicit Feedback, UAI'09, pp. 452–461, 2009.
- [18] Ruslan Salakhutdinov and Andriy Mnih, Probabilistic Matrix Factorization, 20th International Conference on Neural Information Processing Systems (NIPS'07), pp. 1257-1264, 2007.
- [19] Badrul Sarwar, George Karypis, Joseph Konstan, and John Riedl, Application of Dimensionality Reduction in Recommender System – A Case Study, ACM WebKDD Workshop, 2000.
- [20] Badrul Sarwar, George Karypis, Joseph Konstan, and John Riedl, Item-based Collaborative Filtering Recommendation Algorithms, 10th International Conference on World Wide Web (WWW'01), pp. 285-295, 2001.
- [21] Lei Shi, Trading-off Among Accuracy, Similarity, Diversity, and Long-tail: A Graph-based Recommendation Approach, 7th ACM Conference on Recommender Systems (RecSys'13), pp. 57-64, 2013.
- [22] Yuya Shiraishi and Yasufumi Takama, Proposal on matrix-based collaborative filtering using personal values, IEEE 10th International Workshop on Computational Intelligence and Applications (IW-CIA2017), 2017.
- [23] Yasufumi Takama, Ryori Misawa, Yu-Sheng Chen, Shunichi Hattori, and Hiroshi Ishikawa, Proposal of Hybrid Recommender Systems Based on Personal Values-based Collaborative Filtering, 7th International Symposium on Computational Intelligence and Industrial Applications (ISCIIA2016), SM-GS3-01, 2016.
- [24] Yasufumi Takama, Takayuki Yamaguchi, and Shunichi Hattori, Personal Values-Based Item Modeling and its Application to Recommendation with Explanation, Journal of Advanced Computational Intelligence and Intelligent Informatics (JACIII), Vol. 20, No. 6, pp. 867-874, 2016.
- [25] Nava Tintarev and Judith Masthoff, A Survey of Explanations in Recommender Systems, 2007 IEEE 23rd International Conference on Data Engineering Workshop (ICDEW'07), pp. 801-810, 2007.
- [26] Donald E. Vinson, Jerome E. Scott, and Lawrence M. Lamont, The role of personal values in marketing and consumer behavior, Journal of Marketing. Vol. 41, No. 2, pp. 44-50, 1977.
- [27] Wen Wu, Li Chen, and Liang He, Using Personality to Adjust Diversity in Recommender Systems, 24th ACM Conference on Hypertext and Social Media (HT'13), pp. 225-229, 2013.
- [28] Cai-Nicolas Ziegler, Sean M. McNee, Joseph A. Konstan, and Georg Lausen, Improving Recommendation Lists Through Topic Diversification, the 14th International Conference on World Wide Web (WWW'05), pp. 22-32, 2005.